Journal of Agricultural Machinery
Vol. 11, No. 2, Fall- Winter 2021, p. 263-275

نشریه ماشین‌های کشاورزی
جلد ۱۱، شماره ۲، نیمسال دوم ۱۴۰۰، ص ۲۷۵-۲۶۳

مقاله علمی-پژوهشی

مدل‌سازی فرآیند خشک شدن برگه سیب‌زمینی در خشک‌کن مایکروویو به کمک شبکه‌عصبی مصنوعی و بینایی ماشین

سمیه رضایی[۱]، ناصر بهروزی خزاعی[۲*]، حسین درویشی[۲]

تاریخ دریافت: ۱۳۹۷/۱۱/۰۲
تاریخ پذیرش: ۱۳۹۸/۰۳/۲۹

چکیده

در این پژوهش بررسی سینتیک خشک شدن چیپس سیب‌زمینی و مدل‌سازی آن در یک خشک‌کن مایکروویو با سامانه ثبت تصویر به‌صورت بلادرنگ و اعمال سطوح توان متغیر در طی فرآیند خشک کردن انجام گرفت. در خشک‌کن مورد نظر دو سری آزمایش انجام گرفت، سری اول با سه سطح چگالی توان ۲/۶۷، ۴ و ۸ $W\ g^{-1}$ با دو حالت چگالی توان ثابت و متغیر برای بررسی و مدل‌سازی سینتیک تغییرات محتوای رطوبتی و سری دوم با دو سطح ۳ و ۵ $W\ g^{-1}$ برای ارزیابی مدل‌های ساخته شده استفاده شد. همچنین چروکیدگی محصول به کمک الگوریتم پردازش تصویر توسعه داده شده اندازه‌گیری شد. دو مدل شبکه عصبی، اولی با ورودی‌های زمان و چگالی توان و دومی با ورودی‌های نسبت چروکیدگی و چگالی توان برای مدل‌سازی و پیش‌بینی تغییرات محتوای رطوبتی توسعه داده شدند. نتایج ارزیابی مدل‌ها نشان داد که مدل دوم با همبستگی ۰/۹۹۴ و خطای ۰/۰۶۷ نسبت به مدل اول با همبستگی ۰/۹۶۱ و خطای ۰/۱۷۳ دارای قابلیت اعتماد و اطمینان بیشتری برای پیش‌بینی تغییرات محتوای رطوبتی می‌باشد.

واژه‌های کلیدی: چروکیدگی، چگالی توان مایکروویو، سینتیک محتوای رطوبتی

مقدمه

خشک کردن فرآیندی جهت حذف رطوبت از مواد به‌منظور جلوگیری از فساد و تغییرات شیمیایی و در نتیجه نگهداری طولانی‌مدت آن‌ها می‌باشد. به‌طور کلی هدف از خشک کردن محصولات کشاورزی؛ ذخیره‌سازی طولانی‌مدت، تسهیل انبارداری، کاهش هزینه‌های بسته‌بندی و حمل و نقل می‌باشد. انتخاب روش مناسب برای خشک کردن محصول، بر کیفیت نهایی آن تأثیرگذار است. خشک کردن به روش هوای گرم یکی از مرسوم‌ترین روش‌های خشک کردن به‌علت سادگی و قیمت پایین می‌باشد، با این حال منجر به کاهش کیفیت محصول تولیدی می‌شود و همچنین نیاز به زمان طولانی برای خشک کردن دارد (Seremet *et al*., 2015; Bahmanpour *et al*., 2017).

استفاده از تکنیک مایکروویو برای خشک کردن دارای مزایایی از جمله تسریع فرآیند، افزایش کیفیت نهایی محصول خشک شده و کاهش مصرف انرژی می‌باشد. وجود مشکلاتی که در روش‌های سنتی خشک کردن وجود دارد، باعث شده است که مطالعه روش‌های نوین از جمله مایکروویو، با هدف بهینه‌سازی فرآیند خشک کردن چه از نظر زمان و انرژی و چه از نظر کیفیت نهایی ضروری باشد (Sharifian *et al*., 2013). دمای محصول طی فرآیند خشک کردن و توان مایکروویو، مهمترین عوامل در خشک کردن محصولات کشاورزی به روش مایکروویو هستند. این دو عامل به‌طور قابل توجهی روی پارامترهای فرآیند مانند زمان خشک شدن، منحنی خشک شدن، سرعت خشک شدن، راندمان خشک شدن و کیفیت نهایی محصول تأثیرگذار هستند (Li *et al*., 2010a). پژوهش‌های صورت گرفته برای کنترل بهتر فرآیند خشک کردن در خشک‌کن مایکروویو نشان دادند که بهتر است توان مایکروویو در طول فرآیند خشک کردن کاهش یابد. این دلایل عبارتند از: ۱- در طول فرآیند خشک کردن با مایکروویو؛ حجم، جرم و محتوای رطوبتی محصول به‌طور پیوسته تغییر کرده و کاهش می‌یابد، بنابراین این تفاوت‌ها و تغییرات نیازمند یک توان متغیر برای رسیدن به یک بازده کلی بهتر است (Li *et al*., 2010b)، ۲- طی فرآیند خشک کردن با مایکروویو؛ با تبخیر و کاهش آب قابل دسترس، توان جذب شده توسط محصول کاهش می‌یابد و در نتیجه به‌منظور صرفه‌جویی در انرژی و محافظت از تجهیزات و محصول، باید سطح توان مایکروویو را کاهش داد (Monteiro *et al*., 2015)، ۳- در صورت ثابت ماندن سطح توان در طول فرآیند، با کاهش آب و در نتیجه جرم و حجم محصول، چگالی توان مایکروویو در انتهای فرآیند به‌شدت افزایش یافته که منجر به افزایش دما به‌صورت نامطلوبی می‌شود (Li *et al*., 2010a;

۱- دانش‌آموخته کارشناسی ارشد گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران
۲- استادیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران
(*- نویسنده مسئول: Email: n.behroozi@uok.ac.ir)
DOI: 10.22067/jam.v11i2.78709

Bilbao-Sainz *et al*., 2005; Andres *et al*., 2004; Feng and Tang, 1998). این افزایش شدید دما به‌خصوص در مراحل پایانی فرآیند، سوختگی محصول و کاهش کیفیت از نظر بافت، چروکیدگی و رنگ را در پی دارد (Kone *et al*., 2013).

در خشک کردن توسط مایکروویو، چگالی توان مایکروویو یک عامل مهم است که باید در فرآیندهای مربوط به محصولات کشاورزی مورد توجه قرار بگیرد. این عامل، مقدار توان اعمال شده به محصول در واحد جرم یا حجم می‌باشد. چگالی توان، روی رفتار خشک شدن محصول از جمله سرعت خشک شدن، سینتیک خشک شدن، زمان و بازده خشک کردن تأثیر می‌گذارد (Cheng *et al*., 2006; Hafezi *et al*., 2016).

در صورتی‌که چگالی توان مورد استفاده برای خشک کردن در نظر گرفته نشود، ممکن است کیفیت محصول خشک شده؛ به‌ویژه در مراحل پایانی خشک کردن، پایین بیاید. چراکه در فرآیند خشک کردن توسط مایکروویو، معمولاً یک سطح توان ثابت در سراسر فرآیند اعمال می‌شود، بدون این‌که توان مایکروویو و دمای محصول کنترل شود. در این‌صورت، با گذشت زمان و کاهش جرم محصول، چگالی توان افزایش می‌یابد و ممکن است از ۳ وات بر گرم در ابتدای فرآیند به ۴۰ وات بر گرم در انتهای فرآیند برسد؛ همان‌طور که Li *et al*. (2010a) مشاهده کردند، که این پدیده باعث افزایش شدید دما و فرار حرارتی[1] شده و منجر به ایجاد نقاط داغ[2] و در نتیجه تخریب محصول خشک شده شود.

Kone *et al*. (2013) در پژوهشی که روی محصول گوجه‌فرنگی انجام دادند، به این نتیجه رسیدند که با ثابت نگه‌داشتن چگالی توان مایکروویو (یعنی با پیشروی فرآیند و کاهش جرم، توان اعمالی را کاهش دادند تا چگالی توان ثابت بماند، کیفیت محصول افزایش یافته و محصول بافت و ساختار بهتر، چروکیدگی کمتر و ظرفیت بازجذبی بهتری نسبت به حالتی که کنترل چگالی توان صورت نگرفت، پیدا کرد. همچنین، از ایجاد نقاط داغ روی محصول جلوگیری شد.

در طی فرآیند خشک کردن، محصول دچار تغییراتی در بافت و ساختار خود می‌شود که در نتیجه تبخیر آب صورت می‌گیرد و باعث می‌شود حجم محصول تغییر کرده و منقبض گردد. به این تغییرات، چروکیدگی گویند که از ابتدا تا انتهای فرآیند خشک کردن، ادامه دارد. میزان چروکیدگی به عوامل مختلفی از جمله میزان رطوبت اولیه محصول، روش خشک کردن، دمای خشک کردن و دیگر پارامترهای فرآیند بستگی دارد (Figiel, 2006; Omari *et al*., 2018).

در مطالعه‌ای دیگر، رفتار خشک شدن برنج در یک خشک‌کن لایه نازک و همچنین رابطه بین محتوی رطوبتی نمونه‌ها با ویژگی‌های رنگی در شش دما و پنج سرعت هوای مختلف بررسی شد. دمای هوا تأثیر معناداری در سطح ۱٪ روی مقادیر L*a*b* داشت. شبکه‌های عصبی مصنوعی برای پیش‌بینی مقدار رطوبت به‌کار برده شد و از سرعت هوا، دمای هوا و مقادیر L*a*b* به‌عنوان ورودی شبکه، و محتوای رطوبتی نهایی به‌عنوان خروجی شبکه استفاده شد. با استفاده از این روش به‌خوبی مقدار رطوبت تخمین زده شد و R^2(۰/۹۶۳۰) مناسبی در پیش‌بینی رطوبت نمونه‌ها به‌دست آمد (Golpour *et al*., 2015). Hosseinpour *et al.* (2011) از بینایی ماشین برای آنالیز چروکیدگی و تغییرات شکل میگو در یک خشک‌کن لایه نازک استفاده کردند. نتایج نشان داد که، دما و سرعت جریان هوای گرم بر تمام ویژگی‌های مورفولوژیکی مورد نظر در این پژوهش (چروکیدگی، محیط، قطر) تأثیر معناداری در سطح یک درصد داشت. همچنین بیان کردند که بین محتوای رطوبتی نمونه‌ها و ویژگی‌های شکلی آن‌ها، رابطه تقریباً خطی وجود دارد. در پژوهشی دیگر، محققین در یک خشک‌کن هوای گرم از سیستم بینایی ماشین به‌صورت برخط برای بررسی تأثیر پارامترهای فرآیند خشک کردن روی تغییر رنگ نمونه‌های سیب استفاده کردند. آن‌ها، یک شبکه عصبی پرسپترون چندلایه را برای همبستگی ویژگی‌های رنگی و محتوای رطوبتی نمونه‌ها با پارامترهای فرآیند و زمان خشک کردن به‌کار بردند. نتایج نشان داد که تأثیر دمای هوا و ضخامت نمونه‌ها بر تغییرات رنگ نمونه‌ها، نسبت به تأثیر سرعت هوا غالب بود. شبکه عصبی پرسپترون چندلایه، تغییرات رنگ و محتوای رطوبتی را با همبستگی بیشتر از ۰/۹۲ پیش‌بینی کرد (Nadian *et al*., 2015). Rezaei *et al*. (2019) به کمک بینایی ماشین و شبکه عصبی یک مدل بین چروکیدگی و محتوای رطوبتی برگه سیب‌زمینی ارائه کردند و قابلیت مدل پیشنهادی برای کنترل بلادرنگ چگالی توان مایکروویو مورد ارزیابی قرار دادند. نتایج آن‌ها نشان داد که به کمک مدل پیشنهادی می‌توان توان ورودی مایکروویو را بر اساس محتوای رطوبت محصول تنظیم کرد تا چگالی توان در انتهای فرآیند زیاد افزایش پیدا نکند. همچنین مدل‌سازی سینتیک تغییرات محتوای رطوبتی سیر و موسیر در یک خشک‌کن بستر سیال با استفاده از روش‌های مدل‌سازی ریاضی و هوشمند (شبکه عصبی مصنوعی و منطق فازی) نشان داد که روش‌های هوشمند دارای خطای کمتری در مدل‌سازی هستند (Kaveh *et al*., 2019). همچنین نتایج Bai *et al*. (2018) نشان داد که شبکه عصبی دارای قابلیت مناسبی برای مدل‌سازی و پیش‌بینی سینتیک محتوای رطوبتی و رنگ در یک خشک‌کن مایکروویو می‌باشد.

در این پژوهش قابلیت بینایی ماشین برای اندازه‌گیری چروکیدگی در طی فرآیند خشک کردن چیپس سیب‌زمینی در یک خشک‌کن مایکروویو و همچنین توانایی و قابلیت اعتماد شبکه عصبی برای

1- Thermal runaway
2- Hot spots

مدل‌سازی تغییرات محتوای رطوبتی با توجه به متغیر بودن توان مایکروویو در طی فرآیند خشک کردن مورد ارزیابی قرار می‌گیرند.

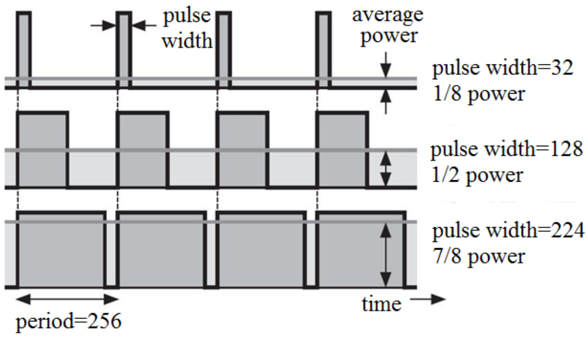
مواد و روش‌ها

توسعه خشک‌کن

از یک دستگاه مایکروویو خانگی (NNST651-1000W-Panasonic) با اعمال تغییراتی در آن، برای توسعه خشک‌کن مایکروویو در کارگاه گروه مهندسی بیوسیستم دانشگاه کردستان استفاده شد. در قسمت مدار کنترلی دستگاه، تغییراتی جهت اعمال کنترل توان انجام شد و همچنین بخش‌هایی به آن اضافه شد که شامل بخش ثبت دما، تصویربرداری و نورپردازی می‌باشد که در ادامه توضیح داده می‌شود.

شناسایی بخش کنترل توان

به‌منظور پیاده‌سازی بخش کنترل توان در این خشک‌کن، ابتدا لازم بود تا سیستم کنترل توان مایکروویو بررسی شود. پس از مطالعه و بررسی‌های لازم مشخص شد که در مایکروویوهای پاناسونیک از روش مدولاسیون پهنای پالس برای کنترل توان استفاده می‌شود. سلسله پالس دیجیتال که یک سیگنال PWM را تشکیل می‌دهد دارای فرکانسی ثابت است که با تغییر عرض پالس میزان متوسط توان سیگنال تغییر می‌یابد (شکل ۱).



شکل ۱– کنترل توان به روش PWM

Fig.1. Control of power with PWM method

نسبت عرض پالس به سیکل آن، چرخه کار سیگنال[1] گفته می‌شود. به‌طور مثال، اگر یک سیگنال PWM یک سیکل ۱۰ میلی‌ثانیه داشته باشد و طول پالس‌های آن دو میلی‌ثانیه باشد، چرخه کار آن، ۲۰٪ خواهد بود.

در این مایکروویو معمولی از ترانسفورماتور برای افزایش ولتاژ ورودی (۱۲۰ ولت متناوب ۶۰ هرتز) به سطح مورد نیاز برای کار مگنترون (۴-۲ کیلو ولت) استفاده می‌شود. با کار کردن در فرکانس پایین (۶۰ هرتز)، ترانسفورماتور نسبتاً ناکارآمد است. چون توان (از طریق اتلاف حرارت) در تبدیل ولتاژ خط به ولتاژ بالا اتلاف می‌شود. در مایکروویوهای مجهز به تکنولوژی اینورتر، یک اینورتر و ترانسفورماتور سبک فرکانس ورودی (۶۰ هرتز) را به یک فرکانس متغیر در بازه ۴۰-۲۰ کیلو هرتز تبدیل می‌کند و کنترل توان مایکروویو به کمک سیگنال PWM ورودی به اینورتر می‌باشد که با تغییر عرض پالس، توان خروجی به‌صورت خطی کنترل می‌شود. برای این‌که بتوان توان مایکروویو را کنترل نمود و با سطح توانی دلخواه مگنترون را روشن کرد، مدار کنترلی خود مایکروویو قطع گردید و یک سامانه کنترل طراحی شده جدید، که شامل یک کامپیوتر، یک کارت DAQ و برنامه نوشته شده در نرم‌افزار LabVIEW (V17.6, 2017) بود، جایگزین مدار کنترلی سیستم گردید. برنامه‌ی نوشته شده در نرم‌افزار LabVIEW با استفاده از بلوک تولید سیگنال[2]، یک سیگنال آنالوگ ایجاد کرده و از طریق کارت DAQ به مدارکنترلی مایکروویو می‌فرستاد و مگنترون شروع به کار می‌کرد (شکل ۲). با تغییر چرخه کار این سیگنال در برنامه نوشته شده مگنترون با سطوح توانی مختلفی می‌توانست کار کند. سیگنال مذکور، سیگنال آنالوگ از نوع مربعی با فرکانس ثابت ۲۲۰ هرتز، دامنه متغیر بین صفر تا پنج ولت و چرخه کار متغیر می‌باشد.

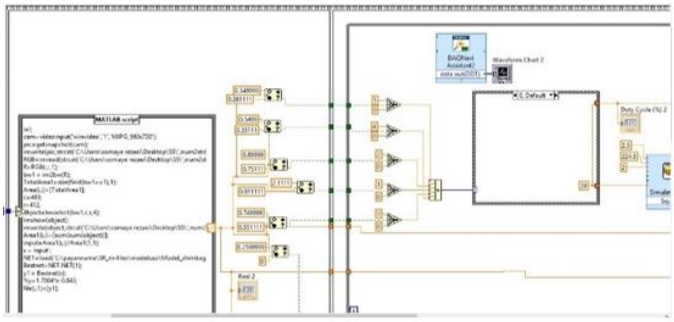
برای توزین نمونه‌ها از یک ترازوی دیجیتال (CAMRY-EK5055) با دقت یک گرم که در فواصل زمانی ۵ دقیقه یک‌بار در ابتدای فرآیند و در ادامه هر ۱۰ دقیقه یک‌بار سینی نمونه‌ها از مایکروویو خارج شده و به‌سرعت توزین شده و دوباره داخل خشک‌کن قرار داده می‌شد، استفاده شد. محتوای رطوبتی و نسبت تغییرات محتوای به کمک روابط (۱) و (۲) محاسبه شدند:

$$MC\,(t) = {(m(t) - m_d)}/{m_d} \qquad (۱)$$

$$MR = {MC(t)}/{MC_0} \qquad (۲)$$

1- Duty cycle

2- Signal generation



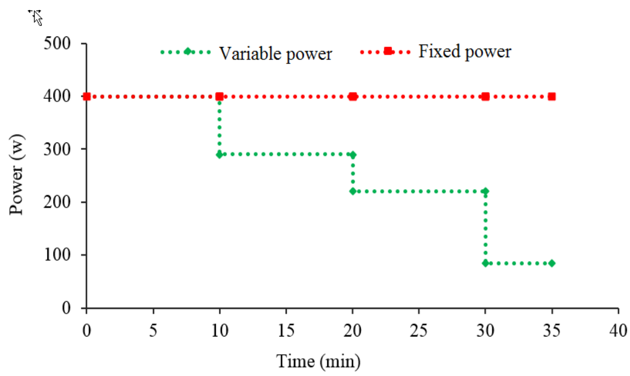
شکل ۲– برنامه نوشته شده در نرم‌افزار لب‌ویو برای کنترل توان مایکروویو به‌صورت برخط

Fig.2. The written program in LabView software of online control of microwave power

که در این روابط t زمان خشک کردن بر حسب دقیقه، m(t) جرم محصول در زمان t بر حسب کیلوگرم، m_d جرم ماده خشک بر حسب کیلوگرم، MC محتوای رطوبتی ماده بر پایه خشک در زمان t، MR نسبت محتوای رطوبتی و MC_0 محتوای رطوبت اولیه ماده بر پایه خشک می‌باشد. نمونه‌های سیب‌زمینی رقم مارفونا از بازار محلی شهرستان سنندج تهیه شد. سیب‌زمینی‌ها قبل از شروع آزمایش، شستشو و پوست‌گیری شد. سپس با استفاده از یک دستگاه ورقه‌کن برقی، نمونه‌ها با ضخامت پنج میلی‌متر برش خورده و بدون هیچ‌گونه پیش‌تیماری برای آزمایش‌ها آماده شد. برای تعیین محتوای رطوبت اولیه محصول، از استاندارد AOAC (1980) استفاده شد که مقدار آن ۸۳٪ بر پایه تر بود. بازده توان مایکروویو ۱۰۰٪ نمی‌باشد. از این‌رو برای تعیین حداکثر توان جذب شده توسط نمونه‌ها، آزمایش کالری‌متری با سه تکرار انجام شد تا توان خروجی مگنترون در هر چرخه کار مشخص گردد (Cheng *et al.*,2006).

تیمارهای آزمایش

آزمایش‌ها در دو سری انجام شد. هدف سری اول، خشک کردن نمونه‌ها به‌منظور مدل‌سازی تغییرات محتوای رطوبتی در طی فرآیند خشک کردن بود. این سری با سه چگالی توان ۲/۶۷، ۴ و ۸W g^{-1} و در سه تکرار و دو حالت مختلف توان ثابت و توان متغیر انجام شد. سری دوم آزمایش‌ها برای ارزیابی مدل ساخته شده صورت گرفت. آزمایش‌ها در سه سطح جرمی ۵۰، ۱۰۰ و ۱۵۰ گرم انجام گرفت. توان اعمالی ۴۰۰ وات بود. به این ترتیب چگالی توان در ابتدای فرآیند برای جرم ۵۰ گرم ۸W g^{-1}، برای جرم ۱۰۰ گرم ۴W g^{-1} و برای جرم ۱۵۰ گرم، ۲/۶۷W g^{-1} در نظر گرفته شد. در ابتدای فرآیند، هر پنج دقیقه یک‌بار و در ادامه هر ۱۰ دقیقه یک‌بار خشک‌کن خاموش شده و نمونه‌ها برای توزین بیرون آورده شده و دوباره بلافاصله داخل خشک‌کن قرار گرفته و خشک‌کن روشن می‌شد. این روند تا پایان فرآیند خشک شدن، یعنی زمانی‌که محتوای رطوبتی نمونه‌ها به ۱۰٪ بر پایه تر برسید، ادامه یافت. در حالت توان ثابت، توان اعمالی ۴۰۰ وات بود و در طول تمام آزمایش برای هر سه تیمار ثابت بود. در حالت توان متغیر، توان با مقدار ۴۰۰ وات در ابتدای فرآیند شروع می‌شد اما در ادامه فرآیند با کاهش محتوای رطوبتی نمونه‌ها و در نتیجه جرم آن‌ها، میزان توان اعمالی کاهش یافت تا چگالی توان خیلی افزایش نیابد (شکل ۳). این کاهش توان با توجه به روند کاهش جرم در آزمایش‌های توان ثابت صورت گرفت. با توجه به نتایج آزمایش‌های توان ثابت، مشخص شد که بیشترین افزایش چگالی توان از مقدار محتوای رطوبتی ۶۸٪ بر پایه تر به پایین صورت می‌گیرد. بنابراین با توجه به مقادیر نسبت رطوبت (MR) یا محتوای رطوبتی و روند کاهش آن، در سه مرحله کاهش توان اعمال شد تا چگالی توان افزایش نیابد.



شکل ۳– کاهش سطوح توان با زمان در تیمار ۸ وات بر گرم

Fig.3. Decrease of power level with time in 8 W g^{-1} experiment

بخش تصویربرداری، نورپردازی و اندازه‌گیری دما

برای تصویربرداری از نمونه‌ها، از یک دوربین وب‌کم (Logitech-C920-HD) استفاده شد. با توجه به‌این‌که لازم بود تصاویر از نمای فوقانی تهیه شود، سقف مایکروویو سوراخ‌کاری شده و دوربین در آن قسمت نصب گردید (شکل ۴). تصاویر به‌صورت برخط و در فواصل زمانی مشخصی، که توزین نمونه‌ها صورت می‌گرفت، تهیه شد. تمام تصاویر در ابعاد ۷۲۰×۹۶۰ پیکسل گرفته شد و برای تحلیل‌های بعدی در رایانه ذخیره شد. برای نورپردازی داخل خشک‌کن از دو مجموعه لامپ SMD استفاده شد. با توجه به محدودیت‌هایی که برای محل نصب این لامپ‌ها وجود داشت، فقط در دو قسمت امکان نورپردازی و نصب لامپ‌ها بود: یکی در دیواره جانبی مایکروویو و دیگری روی درب آن (شکل ۴). برای اندازه‌گیری و ثبت دمای نمونه‌ها از یک حسگر مادون قرمز (GASDNA-IR Compact, Korea) با خروجی ۴-۲۰ میلی‌آمپر و دقت ۱°C استفاده شد. برای نصب این حسگر، سقف مایکروویو به اندازه قطر حسگر سوراخ‌کاری شد (شکل ۴). این حسگر غیرتماسی، طول موج مادون قرمز منتشر شده از سطح شئ مورد نظر را اندازه‌گیری کرده و به یک سیگنال جریان خروجی استاندارد ۲۰-۴ میلی‌آمپر تبدیل می‌کند. با کالیبراسیون حسگر مورد نظر، دمای سطح محصول اندازه‌گیری شد.



شکل ٤- موقعیت نصب دوربین، سنسور مادون قرمز و سیستم روشنایی بر روی خشک‌کن: ۱- دوربین، ۲- سنسور مادون قرمز دما، ۳- سیستم روشنایی

Fig.4. Camera, infrared sensor and lighting system set up position on dryer, 1- Camera, 2- Infrared sensor, 3- Lighting system

الگوریتم پردازش تصویر

الگوریتم پردازش تصویر شامل مراحل زیر می‌باشد:

۱- تصویر اصلی در فضای RGB (شکل ۵-a)، ۲- تحصیل تصویر سطح خاکستری R-B از تصویر اصلی (شکل ۵-b)، ۳- تبدیل تصاویر خاکستری R-B به تصویر باینری با استفاده از آستانه‌گذاری اتسو (شکل ۵-c)، ۴- حذف نواحی کوچک با استفاده از دستور bwareaopen (شکل ۵-d)، ۵- استفاده از دستور imerode برای فرسایش مرز و حذف نویزهای چسبیده به آن به کمک یک عملگر دیسکی و سپس اعمال دستور imdilate برای گسترش و بازسازی مرز به کمک عملگر دیسکی مرحله قبل (شکل ۵-e و f)، ۶- استفاده از دستور bwdist (شکل ۵-g)، ۷- استفاده از دستور watershed برای تقطیع قطعه‌ها (شکل ۵-h).

با توجه به این‌که برای محاسبه چروکیدگی از قطعه سیب‌زمینی که معمولاً در وسط تصویر و در تمام تصاویر در جلوی دوربین قرار گرفته بود، استفاده شد و در ابتدای فرآیند برخی از قطعه‌های دیگر سیب‌زمینی به قطعه مرکزی چسبیده بود، لذا لازم بود تا قطعه مرکزی از دیگر قطعه‌ها جدا شود. برای این منظور، از دستورهای bwdist و watershed استفاده شد.

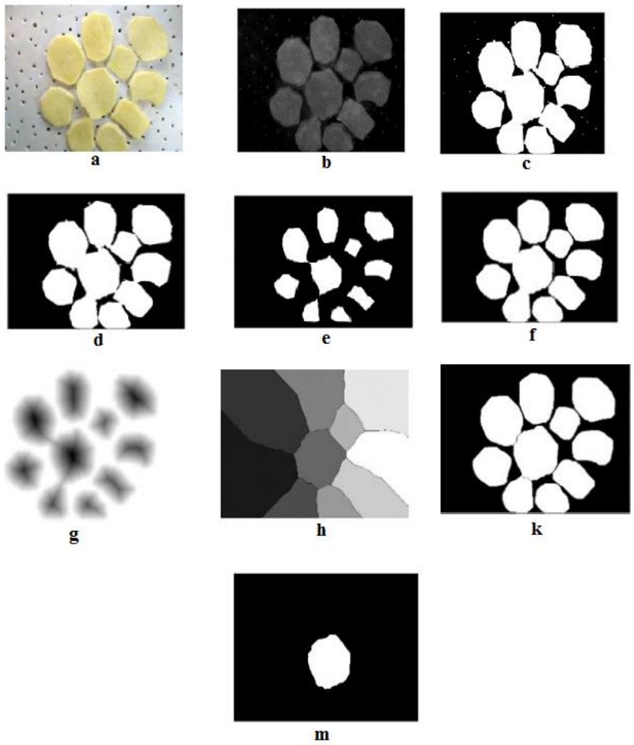
۸- ماسک‌گذاری تصویر مرحله ۷ (شکل ۵-h) با استفاده از تصویر باینری (شکل ۵-d) و به‌دست آمدن تصویر باینری نهایی که تمام قطعه‌ها از یکدیگر به‌خوبی جدا شده‌اند (شکل ۵-k)، ۹- جدا کردن آبجکت مرکزی با استفاده از دستور bwselect (شکل ۵-m).

محاسبه چروکیدگی سطحی

برای اندازه‌گیری میزان چروکیدگی محصول در هر لحظه، از مساحت سطح محصول در تصویر باینری (شکل ۵-m) استفاده شد. به‌این صورت که با شمارش تعداد پیکسل‌های با مقدار ۱ در تصویر مساحت سطح به‌دست آمد و سپس جهت نرمال‌سازی، این مقدار در هر مرحله بر مساحت اولیه تقسیم شد (Behroozi-Khazaei *et al.*, 2013).

$$AR_i = \frac{A_i}{A_0} \qquad (۳)$$

در این رابطه، AR_i نسبت مساحت در لحظه i، A_i مساحت سطح محصول در لحظه i، و A_0 مساحت سطح اولیه محصول است.



شکل ۵- نتایج الگوریتم پردازش تصویر: a) تصویر RGB، b) تصویر R-B، c) تصویر باینری شده، d) حذف نویز، e) فرسایش تصویر، f) اتساع تصویر، g) تصویر bwdist، h) تصویر ناحیه‌بندی شده، k) تصویر با آبجکت‌های جدا شده، m) تصویر مرکزی

Fig.5. The results of image processing algorithm: a) RGB image, b) R-B image, c) Binary image, d) Eliminated the small area, e) Imerode image, f) Imdilate image, g) Bwdist image, h) Watershed image, k) Image with separated object, m) Center object

مدل‌سازی به کمک شبکه های عصبی مصنوعی

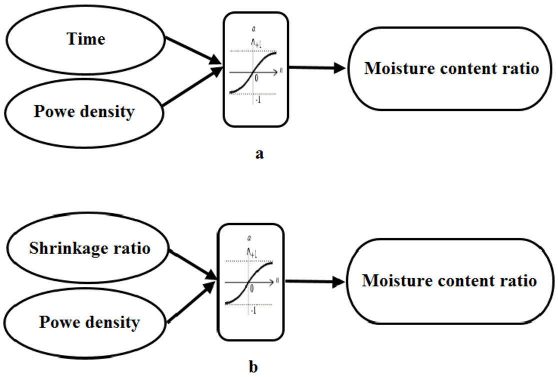
برای ایجاد شبکه عصبی مصنوعی، ابتدا باید معماری شبکه انتخاب گردد. سپس باید شبکه مقداردهی اولیه شده و آموزش آن به‌کمک الگوریتم آموزشی انجام گیرد. شبکه‌ای که در این پژوهش استفاده شد، شبکه عصبی پس‌انتشار پیش‌رو[1] (FFBPNN) سه لایه بود که پارامترهای مورد نیاز برای ایجاد این شبکه مانند تعداد نورون‌های لایه میانی با سعی و خطا تعیین شد. همچنین، برای آموزش شبکه از الگوریتم آموزشی پس‌انتشار گرادیان توأم[2] (که در نرم‌افزار MATLAB تحت عنوان Trainscg شناخته می‌شود) و تابع آستانه تانژانت سیگموئید استفاده شد. دو مدل شبکه عصبی مورد استفاده قرارگرفت. اولی مدل وابسته به زمان که ورودی‌های آن عبارت بودند از زمان و چگالی توان (شکل ۶-a) و دومی مدل مستقل از زمان و ورودی‌های آن عبارت بودند از چروکیدگی و چگالی توان (شکل ۶-b). خروجی هر دو مدل عبارت بود از نسبت تغییرات محتوای رطوبتی (شکل ۶). ابتدا ورودی‌های شبکه عصبی به‌صورت نرمال درآمدند و سپس برای آموزش شبکه کل داده‌ها به سه دسته تقسیم‌بندی شد. ۷۰٪ داده‌ها برای آموزش شبکه، ۱۵٪ برای ارزیابی و ۱۵٪ برای تست به‌کار گرفته شد. برای انتخاب بهترین ساختار شبکه عصبی از ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) استفاده شد که مقادیر RMSE و R به کمک روابط (۴) و (۵) محاسبه شد (Omari *et al.*, 2018):

$$R = \sqrt{1 - \frac{\sum_{i=1}^{N}(O_i - t_i)^2}{\sum_{1}^{N}(O_i - t_m)^2}} \qquad (۴)$$

$$RMSE = \sqrt{\frac{\sum_{1}^{N}(O_i - t_i)^2}{N}} \qquad (۵)$$

که در این روابط O_i مقادیر پیش‌بینی در خروجی شبکه عصبی، t_i مقادیر آزمایشگاهی (واقعی)، O_m میانگین مقادیر واقعی و N تعداد داده‌ها (مشاهدات) می‌باشد.

1- Feed Forward Back Propagation Neural Network
2- Scaled conjugate gradient backpropagation learning algorithm



شکل ٦– مدل‌های ساخته شده با استفاده از شبکه‌های عصبی مصنوعی: a) مدل اول؛ b) مدل دوم

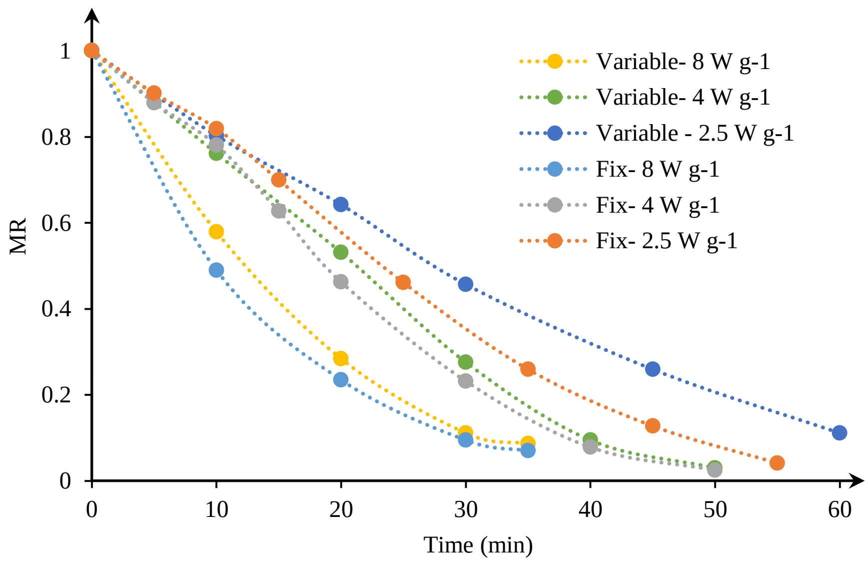
Fig.6. Constructed model with ANN: a) first model; b) second model

سری دوم آزمایش‌ها، جهت ارزیابی مدل‌های ساخته شده و به‌صورت توان متغیر انجام شد. تعداد تیمارهای آزمایشی دو عدد بود که بدین ترتیب انتخاب گردید: جرم ۸۰ گرم و چگالی توان $۵W\ g^{-1}$ و جرم ۱۳۳ گرم و چگالی توان $۳W\ g^{-1}$. مقدار توان اولیه برای هر تیمار ۴۰۰ وات بود. نحوه انجام آزمایش‌ها دقیقاً مانند سری اول آزمایش‌ها بود. این آزمایش‌ها، داده‌های جدیدی فراهم کرد که قبلاً در ساخت و آموزش شبکه‌های ساخته شده استفاده نشده بود. این داده‌ها، به‌عنوان ورودی‌های جدید به شبکه عصبی مدل‌های ساخته شده وارد شدند. هدف از سری دوم آزمایش‌ها این بود تا با پیش‌بینی محتوای رطوبتی و مقایسه آن با مقادیر واقعی، که از توزین نمونه‌ها به‌دست آمد، میزان R و RMSE هر کدام از مدل‌ها محاسبه شود تا قابلیت اطمینان و اعتبار هر کدام از مدل‌ها دوباره سنجیده شود.

نتایج و بحث

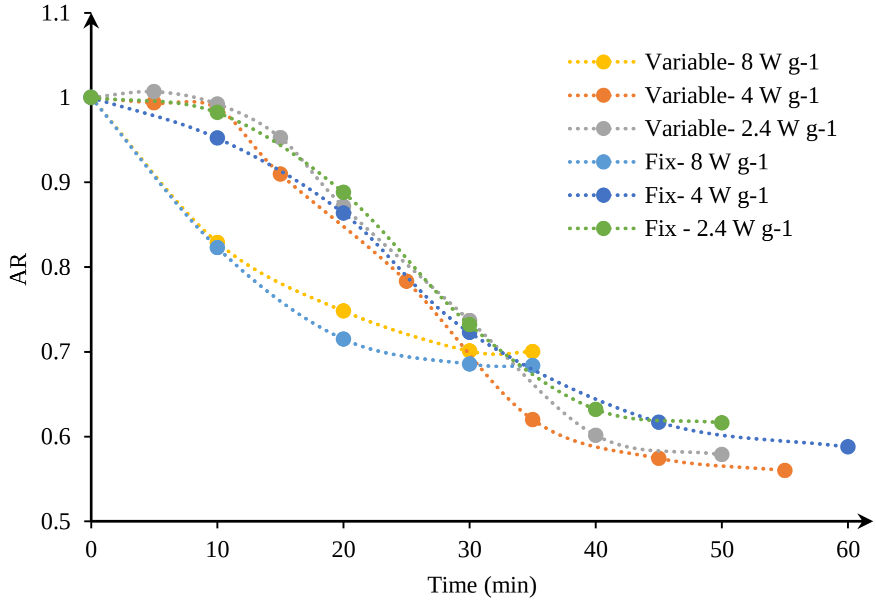
سینتیک خشک شدن سیب‌زمینی

در شکل ۷، تأثیر حالت توان (ثابت یا متغیر) و سطوح چگالی توان بر روند کاهش محتوای رطوبتی با زمان مشخص شده است. نتایج حاصل نشان می‌دهد با افزایش سطح چگالی توان، کاهش محتوای رطوبتی با شیب تندتری همراه بوده است و روند تبخیر آب سرعت بیشتری دارد. اما اختلاف بین دو حالت توان ثابت و متغیر تنها به‌خصوص در انتهای فرآیند فقط در چگالی توان $۲/۵W\ g^{-1}$ مشهود است. در چگالی توان $۴\ W\ g^{-1}$، تا رسیدن محصول به نسبت رطوبت ۰/۶، روند کاهشی مقدار رطوبت در هر دو حالت به‌هم نزدیک بوده است. اما پس از آن حالت توان ثابت شیب تندتری دارد. در چگالی توان $۸\ W\ g^{-1}$ با توجه به بالا بودن چگالی توان تقریباً شدت تغییرات در توان ثابت و متغیر تقریباً یکسان است.



شکل ۷– تغییرات نسبت محتوای رطوبتی با زمان

Fig.7. Variation of moisture content ratio with time



شکل ۸– تغییرات نسبت چروکیدگی با زمان

Fig.8. Variation of shrinkage ratio with time

در شکل ۸ روند تغییرات چروکیدگی محصول و اثر حالت توان و سطوح چگالی توان نشان داده شده است. نتایج نشان‌دهنده آن است در چگالی توان ۸ به خاطر بالا بودن نرخ انتقال رطوبت نرخ چروکیدگی در همان ابتدا خیلی زیاد است و روند تغییرات آن کاملاً متفاوت از دو تیمار دیگر است. برای تیمار ۲/۵ و ۴ ابتدا تغییرات ملموسی تا ۱۰ دقیقه اول دیده نمی‌شود و بعد ازآن چروکیدگی در محصول شدت می‌گیرد و در انتهای فرآیند از نرخ تغییرات آن دوباره کم می‌شود و به‌عبارتی در انتهای فرآیند چروکیدگی به مقدار ثابتی میل می‌کند. همچنین روند تغییرات چروکیدگی نشان می‌دهد که حالت توان تأثیری بر چروکیدگی محصول نداشته و در هر دو حالت توان ثابت و توان متغیر، روند تغییرات چروکیدگی یکسان بوده است. به‌عبارتی، حالت توان تأثیری در روند تغییرات چروکیدگی نداشته است اما سطوح چگالی توان تأثیرگذار بوده است. روند تغییرات چروکیدگی در هر دو حالت با قید دما و بدون قید دما، کاملاً شبیه به تغییرات محتوای رطوبتی محصول در طی فرآیند خشک شدن می‌باشد.

افزایش میزان چروکیدگی محصول در توان‌های ثابت در حالت با قید دما و چگالی توان‌های بالاتر در حالت بدون قید دما، می‌تواند ناشی از نوسانات دمایی و تنش‌های حرارتی باشد. چنان‌که *Li et al.* (2010a) در پژوهش خود بیان کرد که افزایش نوسانات دمایی سبب افزایش تنش‌های حرارتی در محصول و در نهایت افزایش چروکیدگی آن می‌شود. نکته‌ای که لازم است به آن اشاره شود این است که در پژوهش حاضر مقدار نهایی چروکیدگی محصول در تمام تیمارها یکسان است. دلیل آن این است که اصولاً کنترل فرآیند بر اساس این پارامتر صورت گرفته است. یعنی تا زمانی‌که مقدار چروکیدگی به حد مشخصی نرسیده است فرآیند ادامه پیدا کرده و با رسیدن به این مقدار مشخص (۰/۷۱-۰/۶۸) و نسبت رطوبت مشخص ۰/۲۶ یا کمتر (محتوای رطوبتی ۱/۱ بر پایه خشک)، خشک کردن پایان یافته است.

ساختارهای مختلفی از شبکه‌های عصبی با یک لایه و دو لایه پنهان همراه با تابع آستانه تانژانت سیگموئید برای پیش‌بینی نسبت رطوبت آموزش داده شدند. در جدول ۱ و ۲ نتایج ساختارهای مختلف شبکه‌های آموزش داده شده آورده شده است. برای انتخاب شبکه‌ای مناسب، عملکرد شبکه‌های مختلف به کمک داده‌های تست مورد بررسی قرار می‌گیرد و در نهایت با توجه عملکرد آن‌ها، مناسب‌ترین شبکه انتخاب می‌شود.

برای مدل اول نتایج جدول ۱ بیان‌کننده آن است از بین شبکه‌های تک‌لایه، شبکه با ساختار ۱-۳-۲ با مقادیر ۰/۰۷۱۳، ۰/۰۳۳۷ و ۰/۰۶۴۰ برای RMSE و مقادیر ۰/۹۷۶۴، ۰/۹۹۷۳ و ۰/۹۸۰۰ برای R به‌ترتیب برای آموزش، ارزیابی و تست دارای نتایج بهتری نسبت به سایر ساختارهای تک لایه بود. همچنین نتایج نشان داد که شبکه‌های با دولایه پنهان نتایج درخشان‌تری نسبت به شبکه‌های تک لایه ندارند. با این حال از میان شبکه‌های با دو لایه پنهان، شبکه با ساختار ۱-۲-۴-۲ با مقادیر ۰/۰۶۹۹، ۰/۰۳۹۹ و ۰/۰۶۱۲ برای RMSE و مقادیر ۰/۹۷۷۱، ۰/۹۹۵۹ و ۰/۹۸۲۱ برای R به‌ترتیب برای آموزش، ارزیابی و تست دارای نتایج بهتری نسبت به سایر ساختارهای تک لایه و دو لایه می‌باشد و بدین خاطر به‌عنوان بهترین ساختار انتخاب شد. نتایج مشابهی نیز که دلالت بر قابلیت شبکه‌های عصبی برای پیش‌بینی تغییرات محتوای رطوبتی

می‌باشد، گزارش شده است (Omid *et al*., 2009; Abbaszadeh *et al*., 2011).

نتایج مربوط به مدل دوم در جدول ۲ نشان داده شده است. با این حال از میان شبکه‌های با یک و دو لایه پنهان، شبکه دو لایه با ساختار ۱-۲-۲-۲ با مقادیر ۰/۰۷۸۰، ۰/۰۸۱۶ و ۰/۰۹۰۸ برای RMSE و مقادیر ۰/۹۵۹۸، ۰/۹۷۹۹ و ۰/۹۷۴۶ برای R به‌ترتیب برای آموزش، ارزیابی و تست دارای نتایج بهتری نسبت به سایر ساختارها می‌باشد و بدین خاطر به‌عنوان بهترین ساختار انتخاب شد.

جدول ۱- نتایج مدل اول در پیش‌بینی نسبت محتوای رطوبتی

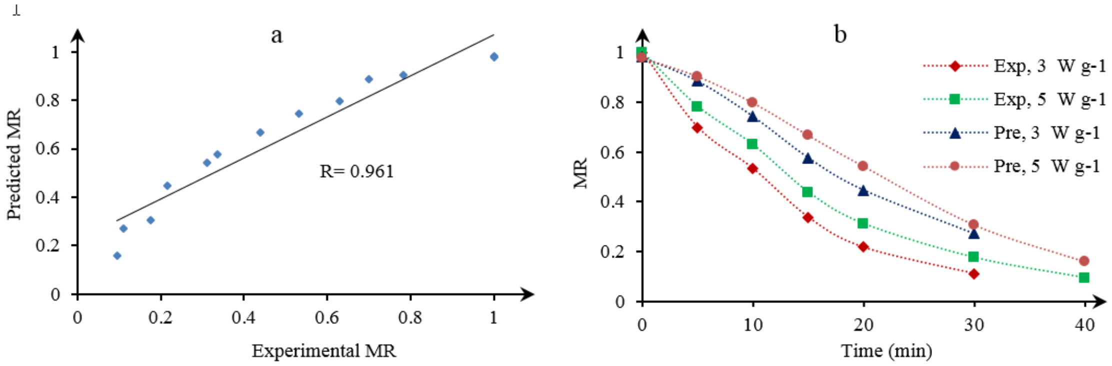
Table 1- Results of the first model to predict the moisture ratio

Number of neuron in hidden layers تعداد نورون در لایه میانی		RMSE جذر میانگین مربعات خطا			R ضریب همبستگی		
First layer لایه اول	Second layer لایه دوم	Train آموزش	Validation ارزیابی	Test تست	Train آموزش	Validation ارزیابی	Test تست
2	0	0.0728	0.0338	0.0649	0.9752	0.9973	0.9790
3	**0**	**0.0713**	**0.0337**	**0.0640**	**0.9764**	**0.9973**	**0.9800**
4	0	0.0732	0.0420	0.0684	0.9752	0.9957	0.9772
5	0	0.0719	0.0377	0.0717	0.9764	0.9964	0.9759
6	0	0.0663	0.0446	0.0690	0.9797	0.9952	0.9699
2	2	0.0766	0.0457	0.0725	0.9699	0.9938	0.9719
2	3	0.0717	0.0385	0.0652	0.9759	0.9963	0.9799
2	4	0.0716	0.0402	0.0690	0.9760	0.9942	0.9773
2	5	0.0755	0.0445	0.0733	0.9741	0.9935	0.9782
3	2	0.0725	0.0374	0.0662	0.9758	0.9969	0.9786
4	**2**	**0.0699**	**0.0399**	**0.0612**	**0.9771**	**0.9959**	**0.9821**
5	2	0.0706	0.0431	0.0675	0.9770	0.9954	0.9803
3	3	0.0706	0.0416	0.0658	0.9770	0.9958	0.9797
3	4	0.0880	0.0493	0.0817	0.9671	0.9947	0.9690
3	5	0.0711	0.0392	0.0713	0.9766	0.9963	0.9760

جدول ۲- نتایج مدل دوم در پیش‌بینی نسبت محتوای رطوبتی

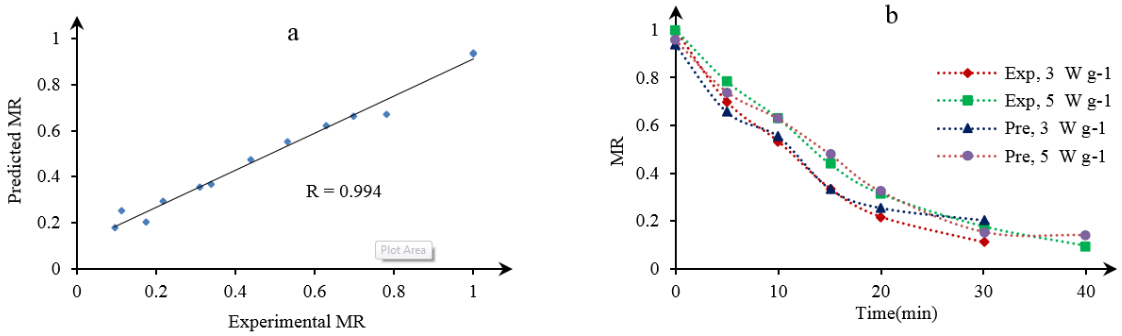
Table 2- Results of the second model to predict the moisture ratio

Number of neuron in hidden layers تعداد نورون در لایه میانی		RMSE جذر میانگین مربعات خطا			R ضریب همبستگی		
Frist layer لایه اول	Second layer لایه دوم	Train آموزش	Validation ارزیابی	Test تست	Train آموزش	Validation ارزیابی	Test تست
2	0	0.1038	0.1045	0.1084	0.9529	0.9685	0.9586
3	0	0.0890	0.0852	0.0912	0.9635	0.9800	0.9707
4	0	0.0890	0.0932	0.1042	0.9633	0.9775	0.9686
5	0	0.1014	0.0979	0.1123	0.9525	0.9718	0.9498
6	0	0.0887	0.1016	0.1144	0.9646	0.9734	0.9596
7	0	0.0984	0.1157	0.1356	0.9617	0.9629	0.9396
2	**3**	**0.0878**	**0.0918**	**0.0890**	**0.9642**	**0.9764**	**0.9743**
2	4	0.1000	0.0987	0.0980	0.9577	0.9729	0.9630
2	5	0.0970	0.1036	0.1139	0.9568	0.9708	0.9586
2	6	0.1041	0.1107	0.1190	0.9457	0.9646	0.9506
2	**2**	**0.0908**	**0.0816**	**0.0780**	**0.9598**	**0.9799**	**0.9746**
3	2	0.0868	0.0854	0.0835	0.9645	0.9782	0.9723
4	2	0.0968	0.0991	0.1030	0.9578	0.9740	0.9604
5	2	0.0885	0.0978	0.0978	0.9536	0.9576	0.9230
3	2	0.0833	0.0836	0.0817	0.9667	0.9799	0.9770
3	3	0.0940	0.0934	0.1003	0.9618	0.9751	0.9589
3	4	0.0965	0.0972	0.1085	0.9610	0.9725	0.9595
3	5	0.0982	0.1188	0.1417	0.9575	0.9620	0.9438



شکل ۹- ارزیابی مدل اول به کمک سری دوم آزمایش‌ها

Fig.9. Validation of first model with second experiment data set



شکل ۱۰- ارزیابی مدل دوم به کمک سری دوم آزمایش‌ها

Fig.10. Validation of second model with second experiment data set

نتایج ارزیابی مدل اول توسط سری دوم آزمایش‌ها در شکل ۹ نشان داده شده است. نتایج شکل ۹ -الف نشان می‌دهد که این مدل به‌خوبی قادر نیست روند تغییرات محتوای رطوبتی را بر حساب زمان پیش‌بینی کند هرچند در شکل ۹- ب بین داده‌های واقعی و پیش‌بینی همبستگی خوبی (۰/۹۶۱) برقرار است ولی RMSE پیش‌بینی ۰/۱۷۳ است که مقدار آن خیلی زیاد می‌باشد. این نتایج ارزیابی نشان می‌دهد که هرچند دقت مدل‌سازی بیشتر بوده ولی قابلیت اطمینان مدل بسیار پایین است. نتایج ارزیابی مدل دوم توسط سری دوم آزمایش‌ها در شکل ۱۰ نشان داده شده است. شکل ۱۰- الف نشان می‌دهد که این مدل به‌خوبی قادر هست روند تغییرات محتوای رطوبتی را بر حساب زمان پیش‌بینی کند. همچنین شکل ۹- ب نشان می‌دهد بین داده‌های واقعی و پیش‌بینی همبستگی ۰/۹۹۴ و خطای پیش‌بینی ۰/۰۶۷ می‌باشد. این نتایج نشان می‌دهد که مدل دوم که در آن چروکیدگی و چگالی توان به‌عنوان ورودی و نسبت رطوبت به‌عنوان خروجی می‌باشد، دارای قابلیت اطمینان و اعتماد بالایی برای پیش‌بینی تغییرات محتوای رطوبتی در طی فرآیند خشک کردن می‌باشد. نتایج مشابهی توسط Nadian *et al.* (2017) و Martynenko and Yang (2007) که از بینایی ماشین و ویژگی‌های استخراجی از تصویر برای پیش‌بینی تغییرات محتوای رطوبتی استفاده کرده بودند، گزارش شده است. همچنین این پژوهشگران از این قابلیت بینایی ماشین برای کنترل بلادرنگ فرآیند خشک کردن استفاده کرده‌اند که نشان از اهمیت توسعه مدل‌های پیش‌بینی تغییرات محتوای رطوبتی بر مبنای ویژگی‌های استخراجی از پردازش تصویر محصول در طی فرآیند خشک کردن می‌باشد. همچنین نتایج مدل دوم در مقایسه با نتایج Rezaei *et al.* (2019) (RMSE=۰/۰۹۴ ،R=۰/۹۶۵۶) که فقط چروکیدگی در ورودی شبکه عصبی استفاده شده بود نشان داد که مدل پیشنهادی در پژوهش حاضر (RMSE=۰/۰۶۷ ،R=۰/۹۹۴) دارای دقت بالاتری می‌باشد.

نتیجه‌گیری

در این پژوهش یک خشک‌کن مایکروویو با سامانه ثبت تصویر به‌صورت بلادرنگ و تغییر سطوح توان در طی فرآیند خشک کردن توسعه داده شد. برای مدل‌سازی فرآیند خشک کردن چیپس سیب‌زمینی از مدل شبکه عصبی استفاده شد. در مدل اول زمان و چگالی توان و در مدل دوم نسبت چروکیدگی و چگالی توان به‌عنوان ورودی و در هر دو مدل محتوای رطوبتی به‌عنوان خروجی مدل در نظر گرفته شد. برای داده‌برداری در این خشک‌کن دو سری آزمایش انجام گرفت. سری اول با سه سطح چگالی توان ۲/۶۷، ۴ و ۸ $W\ g^{-1}$

با دو حالت چگالی توان ثابت و متغیر برای مدل‌سازی سینتیک تغییرات محتوای رطوبتی و سری دوم با دو سطح ۳ و ۵ $W\ g^{-1}$ برای ارزیابی مدل‌های ساخته شده استفاده شد. همچنین یک الگوریتم پردازش تصویر برای اندازه‌گیری چروکیدگی محصول در طی فرآیند خشک کردن توسعه داده شد. نتایج نشان داد در مدل اول شبکه با ساختار ۱-۲-۴-۲ با مقادیر ۰/۰۶۹۹، ۰/۰۳۹۹ و ۰/۰۶۱۲ برای RMSE و مقادیر ۰/۹۷۷۱، ۰/۹۹۵۹ و ۰/۹۸۲۱ برای R به‌ترتیب برای داده‌های آموزش، ارزیابی و تست دارای نتایج بهتری نسبت به سایر ساختارهای تک لایه و دو لایه می‌باشد و بدین خاطر به‌عنوان بهترین ساختار انتخاب شد. برای مدل دوم، شبکه با ساختار ۱-۲-۲-۲ با مقادیر ۰/۰۷۸۰، ۰/۰۸۱۶ و ۰/۰۹۰۸ برای RMSE و مقادیر ۰/۹۵۹۸، ۰/۹۷۹۹ و ۰/۹۷۴۶ برای R به‌ترتیب برای داده‌های آموزش، ارزیابی و تست دارای نتایج بهتری نسبت به سایر ساختارها می‌باشد. هرچند نتایج اولیه نشان‌دهنده آن است که مدل اول دارای نتایج بهتری نسبت به مدل دوم می‌باشد ولی نتایج ارزیابی مدل‌ها نشان داد که مدل دوم با همبستگی ۰/۹۹۴ و خطای ۰/۰۶۷ نسبت به مدل اول با همبستگی ۰/۹۶۱ و خطای ۰/۱۷۳ دارای قابلیت اعتماد و اطمینان لازم برای پیش‌بینی تغییرات محتوای می‌باشد.

References

1. AOAC. 1980. Official methods of analysis (13th ed.). Washington, DC: Author.
2. Abbaszadeh, A., A. Motevali, M. H. Khoshtaghaza, and M. Kazemi. 2011. Evaluation of thin-layer drying models and neural network for describing drying kinetics of lasagnas *angustifolia* L. International Food Research Journal 18 (4): 1321-1328.
3. Andres, A., C. Bilbao, and P. Fito. 2004. Drying kinetics of apple cylinders under combined hot air-microwave dehydration. Journal of Food Engineering 63: 71-78.
4. Bilbao-Sainz, C., A. Andres, and P. Fito. 2005. Hydration kinetics of dried apple as affected by drying conditions. Journal of Food Engineering 68: 369-376.
5. Bahmanpour, H., S. M. Sajadiye, M. J. Sheikhdavoodi, and M. Zolfaghari. 2017. The Effect of Temperature and Drying Method on Drying Time and Color Quality of Mint. Journal of Agricultural Machinery 7 (2): 415-426. (In Farsi).
6. Behroozi-Khazaei, N., T. Tavakoli Hashjin, H. Ghassemian, M. H. Khoshtaghaza, and A. Banakar. 2013. Applied machine vision and artificial neural network for modeling and controlling of the grape drying process. Computers and Electronic in Agriculture 98: 205-213.
7. Bai, J. W., H. W. Xiao, H. L. Ma, and C. S. Zhou. 2018. Artificial neural network modeling of drying kinetics and color changes of ginkgo biloba seeds during microwave drying process. Journal of Food Quality, Article ID 3278595, 8 pages.
8. Cheng, W. M., G. S. V. Raghavan, M. Ngadi, and N. Wang. 2006. Microwave power control strategies on the drying process I. Development and evaluation of new microwave drying system. Journal of Food Engineering 76: 188-194.
9. Feng, H., and J. Tang. 1998. Microwave finish drying of diced apples in a spouted bed. Journal of Food Science 63 (4): 679-683.
10. Figiel, A. 2006. Drying kinetics and drying shrinkage of garlic subjected to vacuum-microwave dehydration. Acta Agrophysica 7 (1): 49-58.
11. Golpour, I., R. Amiri-Chayjan, J. Amiri-Parian, and J. Khazaei. 2015. Prediction of paddy moisture content during thin layer drying using machine vision and artificial neural networks. Journal of Agricultural Science and Technology 17: 287-298.
12. Hosseinpour, S., Sh. Rafiee, and S. S. Mohtasebi. 2011. Application of image processing to analyze shrinkage and shape changes of shrimp batch during drying. Drying Technology 29 (12): 1416-1438.
13. Hafezi, N., M. J. Sheikhdavoodi, S. M. Sajadiye, and M. E. Khorasani Ferdavani. 2016. The study of some physical properties and energy aspects of potatoes drying process by the infrared-vacuum method. Journal of Agricultural Machinery 6 (2): 463-475. (In Farsi).
14. Kone, K. Y., C. Druon, E. Z. Gnimpieba, M. Delmotte, A. Duquenoy, and J. C. Laguerre. 2013. Power density control in microwave assisted air drying to improve quality of food. Journal of Food Engineering 119 (4): 750-757.
15. Kaveh, M., Y. Abbaspour-Gilandeh, R. Amiri Chayjan, and R. Mohammadigol. 2019. Comparison of mathematical modeling, artificial neural networks and fuzzy logic for predicting the moisture ratio of garlic and shallot in a fluidized bed dryer. Journal of Agricultural Machinery 9 (1): 99-112. (In Farsi).
16. Monteiro, R. L., B. A. M. Carciofi, A. M. Jr, and J. B. Laurindo. 2015. How to make a microwave vacuum dryer with turntable. Journal of Food Engineering 166: 276-284.
17. Martynenko, A. I. 2006. Computer-vision system for control of drying processes. Drying Technology 24: 879-888.

18. Martynenko, A. I., and S. Yang. 2007. An intelligent control system for thermal processing of biomaterials. In: Proceedings of the IEEE International Conference on Networking, Sensing and Control, London, UK, 15-17, April.
19. Nadian, M. H., Sh. Rafiee, M. Aghbashlo, S. Hosseinpour, and S. S. Mohtasebi. 2015. Continuous real-time monitoring and neural network modeling of apple slices color changes during hot air drying. Food and Bioproducts Processing 94: 263-274.
20. Nadian, M. H., M. H. Abbaspour-Fard, A. Martynenko, and M. R. Golzarian. 2017. An intelligent integrated control of hybrid hot air-infrared dryer based on fuzzy logic and computer vision system. Computers and Electronics in Agriculture 137: 138-149.
21. Li, Z., G. S. V. Raghavan, and V. Orsat. 2010a. Temperature and power control in microwave drying. Journal of Food Engineering 97 (4): 478-483.
22. Li, Z., G. S. V. Raghavan, and V. Orsat. 2010b. Optimal power control strategies in microwave drying. Journal of Food Engineering 99 (3): 263-268.
23. Omari, A., N. Behroozi-Khazaei, and F. Sharifian. 2018. Drying kinetic and artificial neural network modeling of mushroom drying process in microwave-hot air dryer. Journal of Food Process Engineering e12849.
24. Omid, M., A. Baharlooei, and H. Ahmadi. 2009. Modeling drying kinetics of pistachio nuts with multilayer feed-forward neural network. Drying Technology 27 (10): 1069-1077.
25. Rezaei, S., N. Behroozi-Khazaei, and H. Darvishi. 2019. Microwave power adjusting during potato slice drying process using machine vision. Computers and Electronics in Agriculture 160: 40-50.
26. Sharifian, F., A. Modarres-Motlagh, M. H. Komarizade, and A. N. Nikbakht. 2013. Color change analysis of fig fruit during microwave drying. International Journal of Food Engineering 9 (1): 107-114.
27. Seremet, L., E. Botez, O. V. Nistor, D. G. Andronoiu, and G. D. Mocanu. 2015. Effect of different drying methods on moisture ratio and rehydration of pumpkin slices. Food Chemistry 195: 104-109.

Journal of Agricultural Machinery
Vol. 11, No. 2, Fall- Winter 2021, p. 263-275

نشریه ماشین‌های کشاورزی
جلد ۱۱، شماره ۲، نیمسال دوم ۱۴۰۰، ص ۲۷۵-۲۶۳

Modeling of Potato Slice Drying Process in a Microwave Dryer using Artificial Neural Network and Machine Vision

S. Rezaei[1], N. Behroozi-Khazaei[2*], H. Darvishi[2]

Received: 22-11-2019
Accepted: 19-06-2019

Introduction

Microwave drying compared to conventional hot air drying has many benefits to apply in food drying processes such as volumetric heating, high thermal efficiency, shorter drying time and improved product quality. In conventional microwave drying method, a fixed microwave power was used during the drying process. However, the water of the product evaporated and mass of product decreased over the time that resulted in microwave power density (MPD) increasing during the drying process. Increasing the power density, especially at the end of the process, sharply increased the product temperature. High temperature of products led to the deterioration of the product quality. Most research used variable microwave power program for preventing the risk of overheating and charring of product. The evaporation of the water causes the shrinkage of product. Therefore, many studies have used machine vision for measuring the shrinkage and this technology has been used in modeling and predicting the MC.

Materials and Methods

The fresh potato samples (*Solanum tuberosum* cv. Santana) with 83% (w.b.) of initial MC were sliced into the chips of 5mm thickness. The developed drying systems consisted of microwave oven, lighting unit and imaging unit, temperature sensor, microwave power adjusting unit and a data acquisition unit (DAQ). A LabVIEW (V17.6, 2017) program was developed to integrate all measurements and adjusting the microwave power during the drying process. In this study, two sets of experiment with different aims have done. The first set of experiments was used for calculating the shrinkage by developed image processing algorithm and MC by offline mass measurement and then data sets were used to investigate the artificial neural networks (ANNs). The second set was used for evaluating the reliability of investigating models. The experiments, in the first set, were done with 8, 4 and 2.67 W g^{-1}. In the variable mode, the power varied in two/three steps with respect to the MC of samples during the drying process. Second set of experiments was done in two variable and constant power modes with 5 and 3 W g^{-1}. An image processing algorithm was developed to measure the shrinkage of potato slice during the drying process. In this study the feed forward ANN with back propagation algorithm was used. Two structures of ANN were used for modeling of MC. In the first model time and power density and the second model shrinkage and power density were used as input. Also moisture ratio was used as an output parameter in two models.

Results and Discussion

The obtained results indicated that for the first model the ANN with 2-3-1 structure had better results than others structures. This structure had 0.0713, 0.0337 and 0.0640 of RMSE and 0.9764, 0.9973 and 0.9800 of R for train, validation and test, respectively. For the second model, the 2-2-2-1 structure of ANN with 0.0780, 0.0816 and 0.0908 of RMSE and 0.9598, 0.9799 and 0.9746 of R for train, validation and test, respectively had better results than other structures. The evaluation of these models with a second data set showed that the second model with shrinkage and power density as input with 0.067 of RMSE and 0.994 of R had better results than the first model with 0.173 of RMSE and 0.961 of R. These consequences expressed that the second model had higher reliability for prediction of MC based on shrinkage and power density during drying process.

Conclusions

In this study, a microwave dryer was developed with a real-time image recording system and a microwave power level program during the drying process. Two ANN models were used for modeling of drying kinetics of the potato slices. Also image processing algorithm was investigated by measuring the shrinkage of potato slice during the drying process. The outcomes revealed that shrinkage as input in the ANN had great effect on MC prediction during the drying process.

Keywords: Microwave power density, Moisture content kinetic, Shrinkage

---

1- MSc Graduated of Biosystems Engineering Department, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran
2- Assistant Professor of Biosystems Engineering Department, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran
(*- Corresponding Author Email: n.behroozi@uok.ac.ir)